

BAB I

PENDAHULUAN

1.1 Latar Belakang

Di era digital ini, informasi dapat tersebar dengan cepat melalui berbagai platform media, terutama internet. Berita telah menjadi bagian dari kehidupan sehari-hari. Berita menjadi bagian yang sangat penting dalam kehidupan sehari-hari, memberikan informasi terkini mengenai kejadian-kejadian yang terjadi di sekitar, baik di tingkat lokal, nasional, maupun internasional. Namun, dengan semakin cepatnya aliran berita, sering kali orang merasa kesulitan untuk mencerna informasi yang banyak dalam waktu yang terbatas. Hal ini membuat banyak orang cenderung melewatkan beberapa informasi penting.

Menurut data dari Kementerian Komunikasi dan Informatika (Kominfo) pada Januari 2024, jumlah pengguna internet dengan 79,5% atau sekitar 221.563.479 dari 278.600.000 penduduk di Indonesia (Kementerian Komunikasi dan Informatika 2024). Hal ini menunjukkan betapa pentingnya internet sebagai sumber utama berita, yang memungkinkan masyarakat untuk tetap terinformasi tentang peristiwa-peristiwa terkini. Berdasarkan data Dewan Pers, saat ini terdapat 1.800 media yang terverifikasi, dengan 1.015 media siber, 377 televisi, 18 radio, dan 442 media cetak. Meskipun media siber mendominasi dengan jumlah mencapai 3.886, hanya 36% yang terverifikasi oleh Dewan Pers (dewanpers 2024).

Namun, dengan jumlah berita yang terus berkembang dan begitu cepatnya informasi tersebar, terdapat tantangan dalam mencerna semua berita tersebut secara efektif. Untuk mengatasi tantangan ini, peringkasan berita menjadi salah satu solusi yang efisien. Peringkasan berita bertujuan untuk menyajikan informasi utama dari sebuah teks berita dalam bentuk yang lebih singkat dan mudah dipahami. Menurut Samosir dkk, ekstraksi informasi bertujuan untuk mendapatkan sebuah informasi dari sekumpulan teks (Samosir, Toba, dan Ayub 2022). Lebih lanjut, Samosir dkk menyebutkan ekstraksi informasi merupakan strategi yang baik namun membutuhkan banyak waktu dan tenaga. Oleh karena itu, diperlukan peringkasan teks otomatis menggunakan *Natural Language Processing* (NLP).

Peringkasan teks adalah salah satu solusi yang efektif dan menghemat waktu pembaca untuk mendapatkan intisari dari bacaan tanpa harus melalui seluruh teks panjang. Terdapat dua metode peringkasan berdasarkan teknik menghasilkan kalimat ringkasan yakni abstraktif dan ekstraktif (Rully Widiastutik, Lukman Zaman P. C. S. W, dan Joan Santoso 2019) (Putri, Widodo, dan Ajie 2023). Metode abstraktif adalah pendekatan peringkasan dengan menginterpretasi teks asli dan menciptakan kalimat baru yang tidak ada dalam teks asli. Sedangkan, metode ekstraktif merupakan pendekatan peringkasan yang mengambil sebagian kalimat dari teks asli. Peringkasan dapat dilakukan dengan menggunakan dua cara yakni manual dan otomatis. Peringkasan manual dengan membaca secara langsung, mengidentifikasi dan menggabungkan poin utama yang dirangkai kembali dalam sebuah teks yang lebih sederhana. Ini

membutuhkan waktu yang lama (Rully Widiastutik, Lukman Zaman P. C. S. W, dan Joan Santoso 2019).

Dalam analisis komparatif ini, metode peringkasan abstraktif dan ekstraktif dibandingkan menggunakan model FLAN-T5 pada teks berita. Berita memiliki struktur yang khas, dengan elemen-elemen seperti judul, lead, dan isi yang perlu dipertahankan agar informasi tetap jelas dan tidak kehilangan makna. Dengan membandingkan kedua metode ini menggunakan model FLAN-T5, penelitian ini bertujuan untuk menentukan pendekatan yang lebih efektif dalam menghasilkan ringkasan berita yang tetap mempertahankan esensi informasi, mudah dipahami, dan akurat. Selain itu, penelitian ini akan melakukan evaluasi kuantitatif dan kualitatif untuk mengonfirmasi keunggulan masing-masing metode, mengukur sejauh mana ringkasan yang dihasilkan tetap informatif dan tidak menghilangkan konteks penting dari teks aslinya. Dengan demikian, penelitian ini tidak hanya menilai akurasi model dalam menghasilkan ringkasan tetapi juga memastikan bahwa informasi yang diringkas tetap memiliki kelengkapan dan keterbacaan yang optimal.

Peringkasan otomatis dilakukan oleh komputer yang mampu menghasilkan ringkasan dari satu atau lebih dokumen teks. Oleh karena itu, teknologi *Natural Language Processing* (NLP) yang merupakan cabang *Machine Learning* (ML) seperti peringkasan teks modern menjadi semakin krusial dalam membantu pembaca mendapatkan informasi penting secara cepat dan efisien (Tsirmpas dkk. 2024). Solusi peringkasan berita otomatis berbasis ML sebagai upaya pencegahan disinformasi sebenarnya sudah tersedia. Namun, perbedaan

dalam penggunaan jenis peringkasan dan model menyebabkan variasi dalam keakuratan dan kejelasan ringkasan berita. Kirmani dkk (2024) menjelaskan metode-metode yang biasa digunakan dalam merancang model ML untuk peringkasan ekstraktif dan abstraktif. Peringkasan teks ekstraktif terdiri dari tiga langkah yaitu membentuk representasi teks input, menilai atau memberi skor pada setiap kalimat, dan membuat ringkasan. Langkah-langkah ini saling berhubungan. Metode utama untuk menentukan peringkat kalimat dalam pendekatan ekstraksi ringkasan umumnya terbagi menjadi metode statistik dan semantik (Kirmani, Kaur, dan Mohd 2024).

Lebih lanjut, Kirmani dkk menyebutkan metode yang paling banyak digunakan dalam pendekatan ekstraksi ringkasan adalah metode statistik yang mengidentifikasi kalimat penting berdasarkan statistik teks tanpa memperhatikan makna kata atau kalimat. Metode statistik peringkasan ekstraktif berupa *word frequency method*, *TF-IDF method*, *sentence length method*, *uppercase method*, *sentence position method*, *cue-phrase method*, *proper noun method*, dan *numerical data method*. Metode semantik menghasilkan ringkasan yang lebih koheren dengan memahami sentimen atau emosi dari setiap kalimat dalam dokumen, berbeda dengan metode statistik yang sering kali tidak mempertimbangkan makna teks. Berbeda dengan peringkasan ekstraktif, metode untuk ringkasan teks abstraktif secara luas dikategorikan sebagai metode berbasis struktur dan metode semantik. Metode berbasis struktur mewakili dokumen input menggunakan struktur seperti pohon (*tree based*), *template*, dan skema kognitif, di mana informasi penting dienkrpsi. Metode berbasis semantik mengubah

dokumen input menjadi representasi semantik dan mengirimkannya ke *Natural Language Generation* untuk mengidentifikasi frasa kerja dan frasa benda. Model semantik distribusional seperti Word2Vec, Glove, FasText, dan BioBERT menggunakan analisis statistik untuk membangun representasi semantik dalam ruang vektor berdimensi tinggi, dengan tujuan menyederhanakan pemahaman makna kata dari penggunaannya dalam konteks yang berbeda. Karakteristik ini membuat model semantik terdistribusi menjadi pilihan yang unggul untuk aplikasi ekstraksi makna dalam berbagai domain, seperti analisis paper, berita, dan lainnya (Kirmani, Kaur, dan Mohd 2024).

Penelitian yang dilakukan oleh Halim dkk tahun 2022 yang berjudul “Ringkasan Ekstraktif Otomatis pada Berita Berbahasa Indonesia Menggunakan Metode BERT” yang membahas penggunaan metode IndoBERT untuk melakukan ringkasan otomatis berita Indonesia. Dataset yang digunakan yakni IndoSUM. Metode yang diterapkan dalam penelitian ini melibatkan Bidirectional Encoder Representations from Transformers (BERT) dengan tambahan lapisan encoder transformer. BERT digunakan untuk menghasilkan ringkasan berita dengan memilih kalimat-kalimat penting dari teks berita. Dalam penelitian ini, model pre-trained (indolem/indobert-base-uncased) digunakan untuk menghasilkan ringkasan berita dengan nilai F1-Score terbaik untuk ROUGE-1, ROUGE-2, dan ROUGE-L dalam referensi abstraktif dan ekstraktif. Hasil dari penelitian ini menunjukkan bahwa pre-trained model indolem/indobert-base-uncased dapat menghasilkan nilai F1-Score terbaik untuk ROUGE-1 sebesar 57.17, ROUGE-2 sebesar 51.27, dan ROUGE-L sebesar 55.20 pada referensi

abstraktif. Sedangkan untuk referensi ekstraktif, model ini mencapai ROUGE-1 sebesar 84.46, ROUGE-2 sebesar 83.21, dan ROUGE-L sebesar 83.40. Hal ini menunjukkan efektivitas metode yang diusulkan dalam pembuatan ringkasan berita berbahasa Indonesia menggunakan BERT. Penelitian ini memberikan usulan untuk melakukan eksplorasi lebih lanjut menggunakan model transformer lain seperti OpenAI GPT, ALBERT, atau BART. Dengan begitu, ada peluang untuk mengembangkan metode ringkasan berita berbahasa Indonesia yang lebih canggih dan kompleks menggunakan arsitektur berbasis Transformer (Halim, Gunadi, dan Liliana 2022).

Menurut penelitian yang dilakukan oleh Fuadi dkk (2023) pada paper yang berjudul “idT5: Indonesian Version of Multilingual T5 Transformer” menyebutkan model T5 (Text-to-Text Transfer Transformer) adalah model Transformer yang mengubah semua masalah berbasis teks menjadi format teks-ke-teks untuk bahasa Inggris. Model ini dirancang untuk menyelesaikan berbagai tugas Natural Language Processing (NLP) dengan pendekatan yang seragam, di mana input dan output dari model tersebut berupa teks. T5 telah terbukti efektif dalam menyelesaikan berbagai tugas bahasa alami, dan varian multibahasa dari model ini dikenal sebagai mT5 (multilingual T5) yang dapat digunakan untuk berbagai Bahasa (Fuadi, Wibawa, dan Sumpeno 2023). Hal ini lebih jelas diperkenalkan pertama kali pada *paper* “Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer” oleh tim peneliti dari Google Brain yakni Raffel, dkk (2020). Model T5 dirancang untuk menangani berbagai tugas pemrosesan bahasa alami dengan pendekatan "text-to-text", di mana semua

tugas dirumuskan sebagai tugas pemetaan dari teks input ke teks output. Model ini telah menunjukkan kinerja yang sangat baik dalam berbagai tugas NLP dan transfer learning (Raffel dkk. 2023).

Lebih lanjut Raffell, dkk menyebutkan salah satu keunggulan utama dari T5 adalah kemampuannya dalam transfer learning. T5 mampu belajar dan menerapkan pengetahuan yang diperolehnya dari satu tugas ke tugas-tugas lain dengan sangat efektif, termasuk dalam bidang terjemahan mesin, pemahaman bahasa, dan generasi teks. Selain itu, pendekatan "text-to-text" yang digunakan oleh T5 memungkinkannya menangani berbagai jenis tugas NLP dengan metode yang seragam dan konsisten, yang memberikan fleksibilitas dan skalabilitas yang luar biasa. T5 juga dikenal memiliki kemampuan generalisasi yang kuat, memungkinkan model ini untuk beradaptasi dengan berbagai tugas tanpa perlu penyesuaian besar-besaran. Namun, ada beberapa kekurangan yang perlu diperhatikan dalam penggunaan T5. Pelatihan dan penerapan model ini membutuhkan sumber daya komputasi yang besar, seperti GPU yang kuat dan waktu komputasi yang signifikan, menjadikannya mahal dalam hal biaya operasional. Selain itu, meskipun T5 menunjukkan kinerja yang mengesankan, skala data yang diperlukan untuk melatih model ini bisa menjadi keterbatasan, terutama jika data yang digunakan tidak mencakup variasi yang luas. Terakhir, interpretasi hasil dari model T5 bisa menjadi tantangan tersendiri. Karena kompleksitasnya, memahami bagaimana dan mengapa model T5 membuat prediksi tertentu bisa sulit, yang dapat menjadi hambatan dalam beberapa aplikasi yang memerlukan transparansi tinggi.

Pada penelitian yang dilakukan oleh Chung dkk (2022) dengan paper “Scaling Instruction Finetuned Language Models” menyebutkan model FLAN-T5 adalah model bahasa yang telah di-finetuning dengan instruksi untuk meningkatkan kinerja dalam tugas-tugas tertentu. FLAN-T5 hadir untuk meningkatkan kinerja dan fleksibilitas model T5 dalam tugas peringkasan teks, dengan tujuan memberikan hasil yang lebih baik dan mendukung penelitian lanjutan dalam pemrosesan bahasa alami. Model ini didasarkan pada model T5 yang telah di-pre-train dan kemudian disesuaikan dengan instruksi untuk mencapai kinerja yang lebih baik dalam tugas-tugas zero-shot dan few-shot. FLAN-T5 hadir dalam beberapa ukuran berbeda, seperti Small, Base, Large, XL, dan XXL, dengan jumlah parameter yang meningkat seiring dengan ukuran model yang lebih besar. Model FLAN-T5 memiliki sejumlah miliaran parameter dan dapat digunakan untuk berbagai tugas pemrosesan bahasa alami. Namun, penting untuk diingat bahwa model FLAN-T5 harus digunakan dengan hati-hati dan tidak boleh digunakan untuk kasus penggunaan yang tidak etis atau berpotensi merugikan (Chung dkk. 2022).

Menurut Tsirmpas dkk (2024) pada paper “Neural Natural Language Processing for Long Texts: A Survey on Classification and Summarization” menyebutkan FLAN-T5, yang menggabungkan *Fine-tuned Language Model* (FLAN) dengan T5 (*Text-to-Text Transfer Transformer*), menawarkan beberapa kelebihan untuk peringkasan teks, termasuk fleksibilitas dalam pemrosesan informasi lokal, kemampuan transfer learning, dan kemampuan menangani teks panjang. Namun, model ini juga memiliki kekurangan, seperti kompleksitas yang

lebih tinggi, membutuhkan sumber daya komputasi besar, dan ketergantungan pada kualitas dan representativitas data pelatihan. Meskipun demikian, FLAN-T5 menunjukkan potensi besar dalam meningkatkan kinerja peringkasan teks dengan mempertimbangkan kelemahan yang ada. Peringkasan abstraktif cocok diterapkan menggunakan model seperti FLAN-T5, yang dirancang untuk merepresentasikan informasi inti dari teks sumber dalam bentuk ringkasan yang berbeda secara sintaksis dan semantik. Dengan kemampuannya memahami dan menghasilkan teks berkualitas, FLAN-T5 dapat membuat ringkasan singkat namun informatif, mengidentifikasi poin-poin kunci, mengurangi redundansi, dan menyajikan informasi secara ringkas dan lengkap. Meskipun FLAN-T5 terutama digunakan untuk peringkasan abstraktif, model ini juga dapat melakukan peringkasan ekstraktif dengan teknik yang tepat, meski hasilnya mungkin tidak seoptimal peringkasan abstraktif. Kualitas peringkasan ekstraktif dari FLAN-T5 mungkin kurang optimal karena hanya mengekstrak kalimat tanpa interpretasi tambahan, berbeda dengan model yang dioptimalkan khusus untuk tugas ekstraktif (Tsirmpas dkk. 2024).

Dalam penelitian mengenai komparasi berbagai model T5 dan FLAN-T5 yang dilakukan oleh Krishna dkk berjudul “USB: A Unified Summarization Benchmark Across Tasks and Domains” menyoroti pentingnya pemahaman multi-dimensi dalam ringkasan teks dan membandingkan berbagai metode untuk menentukan berbagai pendekatan yang paling efektif. Multi-dimensi peringkasan teks ini merupakan aspek yang kurang mendapat perhatian seperti menilai

faktualitas ringkasan, menghasilkan ringkasan dengan fokus topik tertentu, mencari bukti pendukung ringkasan dan kompresi multi-kalimat dalam ringkasan.

Dengan melihat aspek ini, penelitian ini ditujukan agar dapat menjadi benchmark komprehensif untuk mengevaluasi kemampuan model dalam berbagai peringkasan teks. Dataset penelitian ini mengacu pada artikel Wikipedia yang diambil dari berbagai kategori, termasuk orang, organisasi, acara, dan lainnya. Dataset ini menggunakan bahasa Inggris karena sumbernya berasal dari artikel Wikipedia berbahasa Inggris. Model yang dikomparasi yaitu RoBERTa-Large, T5-Large, FLAN-T5-Large, FLAN-T5-XL, FLAN-T5-XL (multitask), serta percobaan few-shot prompted LLMs (Llama-13B, Vicuna-13B, dan GPT-3.5-turbo). Performa diuji dengan ROUGE, F1, AUC, dan *ExactMatch* dengan fitur *multi-sentence compression, evidence extraction, factuality classification, fixing factuality, abstractive summarization, extractive summarization, topic-based summarization*, serta *Unsupported Span Prediction*. Hasil *fine-tuning* yang didapatkan menunjukkan peringkasan ekstraktif mendapatkan AUC (Area Under Curve) tertinggi pada model FLAN-T5-Large yakni 87,99. Sedangkan, *fine-tuning* FLAN-T5-XL pada peringkasan abstraktif menghasilkan ROUGE (Recall-Oriented Understudy for Gisting Evaluation) tertinggi di antara model lainnya yakni 32,69. Sementara itu, percobaan menggunakan LLMs mendapatkan hasil yang lebih rendah dibandingkan dengan model fine-tuned. Ini mengindikasikan pentingnya *fine-tuning* model bahasa untuk tugas spesifik dalam peringkasan teks daripada mengandalkan pendekatan *few-shot learning* dengan jumlah contoh terbatas (Krishna dkk. 2023).

Penelitian yang dilakukan oleh Xue Yong Fu dkk (2024) pada paper yang berjudul “Tiny Titans: Can Smaller Large Language Models Punch Above Their Weight in the Real World for Meeting Summarization?” berfokus pada eksplorasi efektivitas dan efisiensi *Large Language Model* (LLM) yang lebih kecil untuk tugas ringkasan pertemuan (*meetings*). Penelitian ini menggunakan dua dataset khusus, yaitu In-Domain dari Dialpad dan QMSUM Filtered, dengan ringkasan pertemuan yang dihasilkan oleh GPT-4 menggunakan instruksi panjang, sedang, dan pendek. Penelitian ini mengevaluasi kinerja GPT-4, FLAN-T5, LLaMA-2, GPT-3.5, dan PaLM-2 dalam tugas ringkasan pertemuan, membandingkan efektivitas model besar dengan model FLAN-T5 yang lebih kecil dalam lingkungan industri nyata. Peringkasan yang dilakukan adalah peringkasan abstraktif. Penelitian ini menggunakan metrik ROUGE-1, ROUGE-2, dan ROUGE-L untuk mengukur kualitas ringkasan pertemuan yang dihasilkan oleh berbagai Large Language Models (LLMs) dengan membandingkan kesesuaian unigram, bigram, dan urutan kata dalam ringkasan model terhadap ringkasan referensi. Penelitian ini menunjukkan bahwa meskipun LLM yang lebih besar umumnya berkinerja lebih baik dalam tugas ringkasan, FLAN-T5-Large dengan 780 juta parameter mampu mengungguli beberapa LLM *zero-shot* yang lebih besar dan mencapai kinerja yang sebanding dengan LLM yang lebih besar yang telah *fine-tuned*. Penggunaan LLM yang lebih kecil seperti FLAN-T5-Large memberikan keuntungan dalam biaya inferensi, sumber daya komputasi, dan latensi, menjadikannya pilihan efisien untuk sistem ringkasan pertemuan di lingkungan bisnis. Namun, penelitian ini juga mencatat keterbatasan seperti

penggunaan instruksi yang terbatas dan referensi ringkasan dari GPT-4, yang perlu diteliti lebih lanjut. Penelitian ini mengidentifikasi kebutuhan akan pengembangan dataset yang lebih kaya dan representatif untuk evaluasi yang lebih komprehensif terhadap kinerja LLMs dalam tugas ringkasan pertemuan (Fudkk. 2024).

Penelitian oleh (Halim, Gunadi, dan Liliana 2022) menunjukkan bahwa metode BERT efektif untuk ringkasan berita berbahasa Indonesia, tetapi masih terdapat perbedaan signifikan dalam nilai ROUGE antara referensi ekstraktif dan abstraktif, yang menunjukkan potensi peningkatan kualitas ringkasan. Ada peluang untuk menerapkan metode ini pada model transformer lain seperti T5 dan FLAN-T5. Hal ini diperkuat oleh penelitian (Krishna dkk. 2023), yang menunjukkan bahwa FLAN-T5 memiliki kinerja tinggi dalam berbagai tugas peringkasan, terutama dalam *fine-tuning* untuk tugas spesifik. Berita sebagai bagian dari teks dalam penelitian ini dijadikan dataset untuk melatih FLAN-T5 untuk model peringkasan. Penggunaan model FLAN-T5 dalam penelitian peringkasan berita memanfaatkan integrasi basis pengetahuan dan kemampuan adaptasi domain yang tinggi, meningkatkan akurasi dan relevansi ringkasan berita berbahasa Indonesia secara signifikan. Ada pun kelebihan penggunaan model FLAN-T5 untuk melatih sistem peringkasan berita menawarkan sejumlah keunggulan signifikan. Penggunaan model FLAN-T5 dalam penelitian peringkasan berita memanfaatkan integrasi basis pengetahuan dan kemampuan adaptasi domain yang tinggi, meningkatkan akurasi dan relevansi ringkasan berita berbahasa Indonesia secara signifikan (ProjectPro 2024). Alasan berita bahasa

Indonesia menjadi objek penelitian ini karena menurut (Chung dkk. 2022) tahun 2022 dengan paper berjudul “Scaling Instruction-Finetuned Language Models”, menyebutkan bahasa Indonesia berada pada “*Mid Resource*” yang artinya bahasa ini memiliki jumlah data yang moderat untuk pelatihan dan pengembangan model Bahasa.

Namun, meskipun FLAN-T5 menunjukkan potensi besar dalam peringkasan abstraktif, penggunaannya untuk peringkasan ekstraktif masih kurang dimanfaatkan, terutama dalam konteks berita berbahasa Indonesia. Penelitian lebih lanjut diperlukan untuk mengeksplorasi efektivitas FLAN-T5 dalam peringkasan ekstraktif, mengingat fleksibilitas dan kemampuan transfer learning model ini. Alasan penggunaan FLAN-T5 adalah kemampuannya untuk menangani berbagai tugas NLP dengan pendekatan yang seragam, fleksibilitas dalam pemrosesan informasi, dan kinerja unggul dalam tugas-tugas yang memerlukan pemahaman mendalam dan generalisasi yang kuat.

Oleh karena itu, dalam penelitian ini, penulis bermaksud untuk melakukan komparasi model peringkasan ekstraktif dan abstraktif menggunakan FLAN-T5. Komparasi antara peringkasan abstraktif dan ekstraktif penting karena masing-masing memiliki kelebihan dan kelemahan. Membandingkan keduanya membantu peneliti mengevaluasi kinerja dan efektivitas dalam menghasilkan ringkasan yang akurat dan informatif. Performa yang akan dikaji mencakup tiga aspek yang akan diobservasi ketika membandingkan model peringkasan ekstraktif dan abstraktif yang dikembangkan. Berdasarkan (Liu dan Lapata 2019), tiga aspek tersebut adalah kualitas ringkasan, metrik evaluasi, dan efisiensi model. Ukuran untuk

kualitas ringkasan secara subjektif mencakup koherensi, kefasihan, konsistensi, dan relevansi dari hasil ringkasan yang dihasilkan. Metrik evaluasi yang digunakan adalah ROUGE (ROUGE-1, ROUGE-2, dan ROUGE-L) serta BERTScore, yang mengukur tingkat kesesuaian dan kualitas ringkasan dibandingkan dengan referensi. Sementara itu, efisiensi model diukur berdasarkan kecepatan eksekusi dalam menghasilkan ringkasan serta penggunaan sumber daya komputasi, seperti memori dan waktu pemrosesan

Komparasi model ini berusaha mencapai dua tujuan utama, yaitu melakukan *fine-tuning* pre-trained model FLAN-T5 untuk peringkasan abstraktif dan ekstraktif serta membandingkan model peringkasan abstraktif dan ekstraktif dengan menggunakan FLAN-T5 dilihat dari tiga aspek komparasi. Dengan FLAN-T5, diharapkan penerapan model ini dapat berguna untuk meringkas teks dengan metode yang terbaik dari aspek komparasi tersebut.

1.2 Rumusan Masalah

Rumusan masalah yang akan dibahas adalah sebagai berikut:

- 1) Bagaimana *fine-tuning pre-trained* model FLAN-T5 dilakukan untuk peringkasan abstraktif dengan konfigurasi yang optimal, serta penerapan embeddings FLAN-T5 untuk peringkasan ekstraktif?
- 2) Bagaimana hasil perbandingan model peringkasan abstraktif dan ekstraktif dengan menggunakan FLAN-T5 dilihat dari tiga aspek komparasi yaitu aspek kualitas ringkasan, metrik evaluasi, dan efisiensi model?

1.3 Batasan Masalah

- 1) Teori yang akan digunakan adalah peringkasan abstraktif dan ekstraktif.

- 2) Perancangan model akan menggunakan Bahasa pemrograman Python.
- 3) Model yang digunakan adalah FLAN-T5.
- 4) Data yang digunakan berupa IndoSum.
- 5) Hasil perbandingan metode peringkasan abstraktif dan ekstraktif dengan FLAN-T5 dianalisis berdasarkan tiga aspek utama: kualitas ringkasan, metrik evaluasi, dan efisiensi model.

1.4 Tujuan Penelitian

- 1) Melakukan fine-tuning pre-trained model FLAN-T5 untuk peringkasan abstraktif dengan konfigurasi yang optimal serta menerapkan embeddings FLAN-T5 untuk peringkasan ekstraktif.
- 2) Membandingkan model peringkasan abstraktif dan ekstraktif dengan menggunakan FLAN-T5 dilihat dari tiga aspek komparasi.

1.5 Metodologi

Untuk menyelesaikan masalah pada penelitian ini, metode-metode yang digunakan adalah:

1. Melakukan studi pustaka untuk mempelajari teori mengenai penerapan model FLAN-T5 pada peringkasan teks abstraktif dan ekstraktif.
2. Pengumpulan dataset IndoSum yang terdiri dari teks berita dalam bahasa Indonesia dan pemrosesan data dengan membersihkan data.
3. Pemilihan model dan *fine-tuning* model untuk tugas abstraktif dan ekstraktif.
4. Implementasi model yang telah di-fine-tune untuk tugas peringkasan abstraktif dan ekstraktif.

5. Evaluasi model dengan menggunakan metrik evaluasi otomatis seperti ROUGE DAN BERTScore.
6. Membandingkan hasil peringkasan abstraktif dan ekstraktif berdasarkan tiga aspek komparasi
7. Mengidentifikasi kelebihan dan kekurangan masing-masing pendekatan peringkasan (abstraktif dan ekstraktif) dengan menggunakan model FLAN-T5.
8. Menyimpulkan hasil dari komparasi, memberikan rekomendasi dan usulan penerapan praktis hasil penelitian.

1.6 Sistematika Penulisan

Laporan tugas akhir ini disusun dengan menggunakan sistematika penulisan yang dapat dijelaskan sebagai berikut:

BAB I PENDAHULUAN

Bab ini dimulai dengan penjelasan mengenai latar belakang penelitian yang berjudul “ANALISIS KOMPARATIF UNTUK PERINGKASAN ABSTRAKTIF DAN EKSTRAKTIF PADA TEKS BERITA”. Kemudian dalam bab ini juga dibahas penentuan rumusan dan batasan masalah serta penjelasan tujuan penelitian dan metodologi yang digunakan pada penelitian ini. Pada akhir bab ini dijelaskan mengenai sistematika penulisan yang digunakan.

BAB II LANDASAN TEORI

Bab ini berisi tentang teori-teori yang digunakan sebagai acuan dalam merancang dan mengembangkan tugas akhir meliputi

Peringkasan Teks (abstraktif dan ekstraktif), model FLAN-T5, *Fine-Tuning*, dataset IndoSum, *cosine similarity*, dan pembahasan evaluasi aspek (aspek kualitas, metrik evaluasi, dan efisiensi model).

BAB III ANALISA DAN PERANCANGAN SISTEM

Bab ketiga ini menjelaskan mengenai perancangan pemodelan FLAN-T5 yang digunakan untuk peringkasan abstraktif dan ekstraktif. Perancangan pemodelan ini meliputi pembahasan proses dan tahapan dalam membangun model abstraktif dan ekstraktif, termasuk langkah-langkah pra-pemrosesan dataset, strategi *fine-tuning*, penggunaan model untuk embeddings, dan rancangan parameter yang digunakan.

BAB IV IMPLEMENTASI DAN PENGUJIAN

Bab ini berisikan penjelasan mengenai implementasi model yang dirancang, serta penjelasan singkat mengenai implementasi model terhadap kedua metode peringkasan. Hasil dari pengujian model peringkasan abstraktif dan ekstraktif juga dijelaskan pada bab ini. Dalam pengujian model akan dipaparkan analisis yang dilakukan dari segi aspek kualitas ringkasan, metrik evaluasi, dan efisiensi model berdasarkan hasil pengujian yang digunakan untuk menarik kesimpulan dan saran.

BAB V KESIMPULAN DAN SARAN

Bab ini merupakan penutup dari penelitian yang memuat rangkuman temuan utama berdasarkan hasil yang telah dicapai selama proses penelitian. Kesimpulan akan dirumuskan dari hasil analisis dan pengujian yang dilakukan pada model peringkasan abstraktif dan ekstraktif, dengan mempertimbangkan kinerja model berdasarkan aspek kualitas ringkasan, evaluasi metrik, dan efisiensi penggunaan sumber daya. Selain itu, bab ini juga memberikan rekomendasi untuk pengembangan penelitian lebih lanjut, termasuk usulan peningkatan pada metodologi, implementasi, atau eksplorasi lanjutan yang relevan dengan topik ini.

